图书情报工作
第 63 卷 第 16 期 2019 年 8 月

知识找回场景下推荐系统模拟实现及评价研究*

■ 程秀峰 张孜铭 孟亚琪 范晓莹 杨金庆
华中师范大学信息管理学院 武汉 430079

摘要:[目的/意义]信息过载一直是知识工作者在搜集、处理和创造知识的过程中所面临的主要困境。这种困境导致的结果之一是很难回忆起曾经使用过的文档的内容细节及具体位置,而推荐系统则能减少这样的困难。通过研究对比不同推荐系统在这一任务下的优缺点,可以帮助知识工作者更好地完成回忆任务。[方法/过程]基于相关理论,在同一场景(知识找回)模拟实现并测试了 4 种不同类型的推荐过程,包括基于内容的推荐 CBR、基于协同过滤的推荐 CFR、基于推理网络的推荐 INR 与融入了情境感知的推荐 CAS,根据所确定的若干指标(精确性、情境相关性、预测性、多样性)对推荐效果进行比较。[结果/结论]结果显示,以上推荐系统在帮助用户回忆并找回文档过程中都有各自的优势,而基于情境感知的推荐系统在情境相关性与预测用户行为方面具有较好的效果。

关键词:信息过载 知识找回 推荐系统 情境感知
分类号:G250.76
DOI:10.13266/j.issn.0252-3116.2019.16.008

1 引言

随着互联网规模的急剧扩大与信息数量的几何增长,信息服务领域一直面临着"信息过载"的困境。这种困境的主要表现形式为:个人或系统所接受的信息超过了其接受能力而导致系统故障[1]。根据检索理论而发展出的一般信息检索系统,能从海量数据中"拉取"信息,但无法根据用户当前或历史行为挖掘有效信息,更无法感知用户当前情境来进行合理推荐。而建立在对用户需求预测基础上的信息推荐方案,能更好实现"按需定制服务",也能一定程度上解决信息过载问题[2]。目前,由以下几类模型(算法集)组合的推荐系统发展较为完备:第一类,过滤类。即基于内容或基于协同过滤模型,它们主要针对"用户本身对资源项目的偏好"或"用户-项目(item)"的二元关系进行推荐,该类模型所开发的推荐系统在商业领域(如 B2C 网站、广告、新闻、娱乐)均有成熟应用,且效果明显[3-5]。第二类,标注类。即基于语义(社会化)标签或本体的模型。它们对"用户-资源"两端内容做语义优化和标签描述。在此基础上对用户属性进行建模[6],或对用户和资源进行标签描述和分/聚类[7],并且使得机器能识别用户偏好和资源所蕴含的语义信息,在更广泛的范围内解决信息推荐过程中的"个性化""兴趣偏好发现""资源异构"与"语义偏差"等问题,从而提高推荐的精度[8-9]。第三类,推理类。此类模型基于某种推理规则(inference rules)或机器学习相关方法进行推理决策,在资源网络中找出满意结果[10-11]。第四类,感知类,是在原有模型中融入了情境信息[12],以提高泛在场景下信息推荐服务的效果,此类推荐系统在实际应用中,尚处于发展阶段,成熟的推荐应用较少[13-14]。需要说明的是,以上这四类推荐系统模型并不具有独立性,为了使得推荐效果更佳,往往将这些模型中的两种或多种进行搭配和组合,形成混合推荐系统。

在解决信息过载问题时,许多学者将研究场景设定为网络信息资源的接受与利用,而少有研究面向日常工作中的知识找回(knowledge re-finding)[15]场景。

* 本文系国家自然科学青年项目"基于 QSIM 的图书馆移动用户群体行为模拟与学习兴趣引导研究"(项目编号:71503097)和华中师范大学基本科研业务费资助项目"基于上下文感知技术的交互式移动学习行为研究"(项目编号:CCNU18TS039)研究成果之一。

作者简介:程秀峰(ORCID:0000-0003-2139-2122),副教授,博士,硕士生导师;张孜铭(ORCID:0000-0002-3341-5574),本科生;孟亚琪(ORCID:0000-0002-4017-7180),本科生;范晓莹(ORCID:0000-0003-0369-8312),本科生;杨金庆(ORCID:0000-0002-2228-2462),硕士,通讯作者,E-mail:yjq@mails.ccnu.edu.cn。

收稿日期:2018-10-19 修回日期:2019-01-23 本文起止页码:72-83 本文责任编辑:王传清

日常工作中，知识工作者（knowledge workers）[16]的任务通常包括文档撰写、程序编写、数据分析、文本阅读等，并会在以上任务间频繁切换，这种切换会使得他们经常查阅自己过去曾经浏览过的文档。当这种情况发生时，有可能出现"即使知道存储在某一角落，但依然容易忘记其路径而无法找到它们"的问题。本文将以上场景称为"知识找回"或"知识辅助记忆"，而将以上问题称为"知识找回困难"。

因此，为知识工作者选择合适的推荐系统来帮助其回忆这些文档，能够提高其工作效率、提升工作质量。许多学者在协同推荐的基础上，从各个角度对找回记忆性知识问题进行了研究。例如，利用本体理论[17]、决策系统理论[18]、可靠性及信任度理论[19]等。这些研究大多仅考虑了用户的静态兴趣（static interest），虽然静态兴趣的多维描述会使推荐结果更为丰富，但在知识找回场景下，就会导致另一个逻辑性问题，即："推荐的目的是为了减少信息过载，而不是增加它"。换句话说，知识找回场景下推荐系统的任务是提醒用户"将要"使用什么，而不是用户"喜欢过"什么。这样，如何合理预测用户可能出现的这些需求，对这类推荐系统提出了更高要求。结合一般推荐，笔者认为，知识找回场景下推荐的任务需求可以概括为以下4个特征：

（1）精确推荐。即精确推荐结果集，以减少非相关推荐结果对工作的干扰。

（2）情境相关。提醒用户哪些文档是其过去浏览过且与现在进行的知识工作情境相关的。

（3）行为预测。能够感知下一步可能用到的文档，以减少人机交互复杂度，节省用户导航时间。

（4）多样性。提供多样化推荐结果，以激发用户的知识创造力。

笔者根据上述4个需求的特点设立相关指标，并将前文所述的4种推荐类型放到知识找回这一研究场景，通过记录用户历史行为，描述用户过去工作情境和当前工作情境，建立基于情境感知的推荐模型[20]。预测其有可能忘记或用到的资源。然后将4种推荐效果放到同一个指标体系中，进行统一评价。这对深入研究个性化推荐服务具有重要的理论与现实意义。

2 相关研究

2.1 知识找回

知识找回这一概念源于人们在使用搜索引擎时所产生的"重新访问他们之前观看过的内容"的信息行为。大多数有经验的用户都难以记住最初查询时发现的内容，以致频繁地重新查找信息[21]。雅虎的一项基于查询日志的研究表明，40%的查询试图重新查找过去已经检索过的结果[22]，而在对用户行为进行监测的实验中，得到了更高的该类行为发生比例（44%[23]，58%[24]，81%[25]）。尽管这种找回信息的场景经常发生，但总体成功率低于20%。因此，如何提升信息找回的成功率成为了此类研究的关键问题[26]。研究者们最初将这种工作场景称为"信息找回"（information re－finding），试图通过引入检索系统和推荐系统来解决这一问题。在具体实践中，基于用户信息[27]、基于内容[28]的推荐方式都在信息找回的工作场景中表现出了较好的效果。而随着个人知识管理系统的发展，这种信息找回的行为得到了进一步延伸，人们所需找回的信息不再是单纯的历史检索记录，而是过去经过个人理解加工，对现在进行着的创造性工作有着积极作用的知识[29]，信息找回也逐渐演化为知识找回。因此，如何辅助知识工作者在知识找回场景下更好地工作，这对现有的推荐系统提出了更高的要求。

2.2 推荐系统

从1992年Goldberg推出第一个推荐系统Tapestry[30]以及1994年P. Resnick等推出第一个自动协同过滤系统GroupLens以来[31]，推荐系统研究已经经历了20多年的发展，形成了一个较为独立的研究方向，它与计算机、信息检索、行为认知、管理科学等领域相关。虽然学术界对推荐系统一直没有一个公认且精确的定义，但一些解释也获得了广泛性的认同：①推荐系统的本质是信息发现[32]；②推荐系统可以有效缓解信息过载问题[33]；③推荐系统挖掘"用户－项目"之间的二元关系并基于这种关系建立关联算法[34]等。

在前文所述的4类推荐系统中，第一类推荐系统在理论及应用发展最为成熟，众多学者为解决这类推荐中冷启动、稀疏性、异构性及可扩展性问题[35]，提出了大量改进模型及其应用，并在商业上获得了大量成功应用。

第二类推荐系统在2000年以后逐渐兴起[36]，形成更为精确的个性化推荐方案。此类系统所应用的标注机制很多，包括建立项目本体、标注用户属性、大众（人口或项目）分类等，是对二元关系的某一端进行描述机制的优化。

第三类推荐系统的理论来源于决策支持系统。2002年后，机器学习中关联规则、主题提取与智能决策研究增多[37]，基于案例推理及多Agent引擎的推理

类推荐系统逐渐发展成熟，此类系统以专家知识库为支撑，在案例推荐、系统集成和实时推荐等方面均有较好效果。

第四类推荐系统将采集到的情境信息融入各类推荐结果，从而对系统决策结果的有效性和精确性产生有益影响。现阶段，对情境感知推荐的研究主要集中在情境融合上[38－40]上，即在原有的推荐模型上，融合某种情境信息进行推荐。例如，融合了地理位置信息的电影、广告、新闻推荐等。

然而无论是非情境推荐系统，还是具有情境感知能力的推荐系统，以往研究大都将研究重点放在推荐对象及推荐算法机制上，例如：应用具体推荐算法的商品推荐、文档推荐、音乐推荐等，而忽视了对具体场景的关注，如文档推荐中的知识找回场景。而在个性化服务趋于智能化的今天，根据不同具体场景的构成要素，例如：信息平台（无论是电商网站还是专家系统）、资源类型（无论是同构还是异构）、用户群体（无论是个人还是群体）、需求标准（无论评价指标如何）、感知能力（无论是移动感知还是上下文感知）设计推荐方案时，都要按体裁衣，按需定量，才能获得最优推荐效果。

3 模拟方案

为了评价各类型推荐系统在知识找回场景下的表现，综合分析各类推荐模型的优势与缺点，本文选取 4 种有代表性的推荐系统进行模拟，将模拟得到的推荐列表与用户需求进行匹配，得出测度数据。模拟知识找回场景的基本思路是：给用户分配一项具体工作（例如：浏览文档撰写论文），在该工作中用户需要参考大量文档才能完成。在一个时间周期后，给用户分配另外一种相似的工作（例如：制作论文 PPT），该工作可能要用到前一次工作中的相关文档，各推荐系统需要在第二次工作中对用户可能会用到的前次工作中参考过的文档进行推荐。然后，比对第二次工作中实际用到的文档序列（或用户主观选择的重要文档序列）和第一次工作后经过特定推荐系统处理得出的推荐结果，来得到各推荐系统的测度效果。本文采用离线模拟在线环境的方式，将推荐系统的推荐过程从模拟实验中独立出来，以这样的方式模拟推荐系统，进而评估推荐效果，具有规范性高、数据易得、评估精确的优点。

这一思路的实现过程如下：实验分为 A、B 两个时段。具体为：在时段 A 里，要求用户从 t 个主题（本文实验 $t=3$）中选取一个主题。用户被提供离线检索文档集 $D_t=<d_{t1}...d_{tn}>$，先将 $D(t)$ 分类并预先放置到对应于搜索引擎（或数据库）的目录中，目录名用搜索引擎名代替，作为该搜索引擎的模拟检索结果。每个文件夹包含 F（$F=6$，分别代表 360、搜搜、搜狗、百度、万方、知网）个子文件夹，每个子文件夹中存有该搜索引擎搜到的文档若干。让 k 位（本文实验 $k=20$）用户中的每位用户首先选择一个主题，然后离线使用对应的 $D(t)$ 来写一篇不少于 800 字的文章（文章体裁自定），得到用户文章集合 $C_A=<c_{A1}\cdots c_{Ak}>$。同时，系统得到每位用户在时间段 A 中的实际行为记录 H_{Ai}，作为情境推荐系统的输入。A 时段结束后，要求每位被试者主观选择 15 篇重要文档 M_{Ai}，作为非情境推荐系统的输入。

在相隔 4 周后的 B 时段，召回用户，这次只给用户 u_i 文档集 M_{Ai}，要求用户利用 M_{Ai} 做出一份 5 页的规定格式的 PPT，作为成果集合 $C_B=<c_{B1}\cdots c_{Bk}>$，并得到每位用户实际行为记录 H_{Bi}。同时要求每位用户在 B 时段工作完成之后主观选择 10 篇重要文档 M_{Bi} 并对其打分（1－5）。实验中，A、B 时间段的情境信息由 IE－History－View 工具与 Key logger 工具记录，实验中所记录的情境信息在本文的 4.4 小节中详细介绍，具体实验流程如图 1 所示：

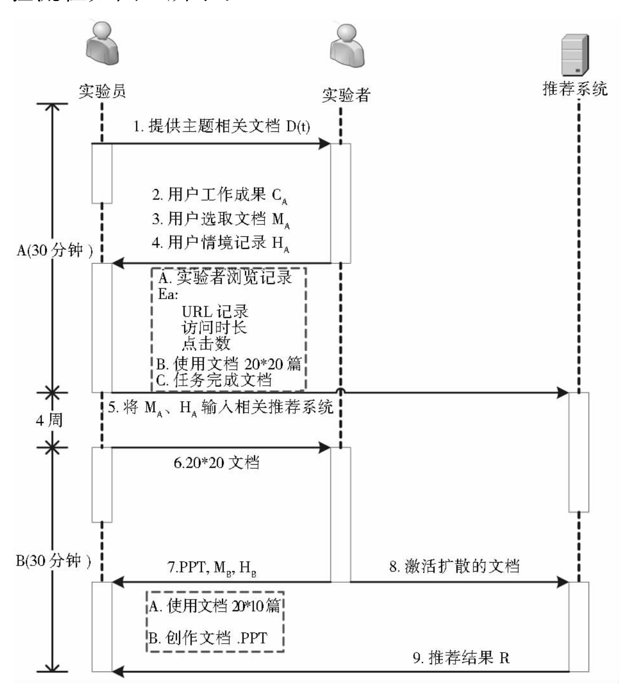


图 1　面向知识找回的推荐系统模拟实验时序

在模拟实验结束后，基于 M_A 与下文各非情境感知模型，得到推荐结果集合 R；基于 M_A、H_A 与下文情境感知模型，得到推荐结果集合 R'，分别比对 R 和 R' 与

M_B 的精确性等指标。

4 知识找回场景下的推荐系统具体实现方法

4.1 内容推荐

基于内容的信息推荐(content-based recommendation,CBR)系统,是根据用户对于资源项目(item)内容的偏好程度,为用户推荐与其偏好相似的项目。因为在知识找回场景中,推荐的对象是过去浏览过的内容,故而可将文档内容看做项目,分词去重后的文档词看做项目元素,用户浏览文档的时长视为用户偏好。其基本思想是:分析用户过去浏览过的文档内容,形成用户偏好的描述;对当前进行的工作项目进行前置过滤,形成项目的内容描述,然后通过比较用户与项目间的相似性来实现推荐[41]。面向知识找回场景的 CBR 系统具有两个模块:预处理模块与推荐模块。前者是针对项目内容进行处理,经过分词、特征抽取(feature extraction)、索引、降维等过程,建立项目 i 的数学或文档描述 $content(i)$。对于后者,首先利用 TF-IDF 算法计算项目元素对于项目的权重,然后基于用户历史记录,创建用户偏好描述,最后利用某效用函数:$R(u,i)=sim(u, content(i))$ 来表示项目内容对于用户 u 的重要程度。具体的推荐过程为:首先通过 IEHisotryView 和分词工具获取用户浏览历史、分词与去除停用词[42],然后借助经典的 TF-IDF 模型(需要最大限度区分不同文档资源),并根据用户历史记录中文档浏览时长,构建目标用户 u_i 对特征词集合 $T=\{t_1,t_2,\cdots,t_k\}$ 的偏好向量 $u_i=\{w_{1,i},w_{2,i},\cdots w_{k,i},\cdots,w_{|T|,i}$。由于任何一个文档资源都可用一个特征词权重组成的向量来表示,通过特征词权重可以最大限度区分不同文档资源。特征词 t_k 对于文档 的重要性程度的归一化计算公式为:

$$W(t_k,d_j)=\frac{TF(t_k,d_j)\times\log\left(\frac{N}{n_k}\right)}{\sqrt{\sum_{1}^{|T|}\left[TF(t_k,d_j)\times\log\left(\frac{N}{n_k}\right)\right]^2}},\ (dj\in D)$$

公式(1)

公式 1 中,$TF(t_k,d_j)$ 表示特征词 t_k 在文档 d_j 中的词频,N 为文档总数,n_k 为出现特征词 t_k 的文档资源数量,T 为特征词数量。然后,根据效用函数计算余弦相似度以实现用户浏览文档再推荐过程,记为:

$$sim(u_i,d_j)=\frac{\sum_k w_{k,j}\cdot w_{k,j}}{\sqrt{\sum_k w_{k,j}^2}\cdot\sqrt{\sum_k w_{k,j}^2}}\qquad 公式(2)$$

公式 2 中,$w_{k,j}$ 表示用户偏好向量权重,$w_{k,j}$ 表示文档向量权重。将上式矩阵化(用户-文档),即得到基于用户浏览历史文档的推荐文档集合,设定阈值可得推荐排名。

4.2 协同过滤推荐

基于协同过滤的信息推荐(collaborative filtering recommendation,CFR)方式与 CBR 的不同之处在于:前者是基于目标用户自身偏好进行推荐目标的选择,而后者是基于 D. Goldberg 等 1992 年提出的这样一种假设,即:"如果一组用户对一些项目的偏好相似,那么他们对其它相关资源的评分也会相似"[43],因此,协同过滤推荐的实质是通过将偏好向量化,进而通过向量间相似性度量方法找到目标用户(或目标项目)的最近邻集(k-nearest neighbor,KNN),并预测用户排序形成 *Top-N* 推荐文档集。若将 CFR 思想引入到知识找回的场景中,可以看做一个小型团队的知识共享过程:通过发现团队其他成员工作时的偏好情况来找回过去浏览过且现在需要的文档。但是,由于知识找回场景的特殊性,进行协同过滤推荐时会存在这样两个问题:一方面,若基于 M_A 集合中的用户选择与否建立 0/1 评分矩阵进行协同,那么会存在 M_A 与用户实际浏览历史 H_A 没有交集,或推荐集合 R 与参照项 H_B 与 M_B 重合率不高,以及稀疏性等问题。另一方面,用户对文档的偏好不仅取决于选择与否,还取决于实际浏览与否,平均停留时间、点击数、文档类型以及用户自身的知识层次等因素。为了克服这两个问题,本文采用基于主观选择与客观记录相结合的方式确定用户偏好,构建最近邻居 KNN,进而产生协同推荐集的方法。基本思想是:①在 M_A 中融入 H_A 中包含的每位用户浏览驻留时间 t_u,确立时间阈 T(>30sec),将 M_A 去 0/1 化,利用扩展的协同推荐方法[44],将稀疏矩阵逐渐填充,使得稀疏因子>0.05。得到所有在同一主题下的用户 i 对所选文档序列 M_{Ai}的评分矩阵。其中用户 u 对文档 i 的评分信息由公式 3 给出。

$$R_{uc}=\left(\frac{t_u}{T}*M_A\right)\qquad 公式(3)$$

对文档 i 和文档 j 都做过评分的用户集合用 $U_{i,j}$ 表示,则文档相似性可用 Person 相关系数度量。

$$sim(i,j)=\frac{\sum_{u\in U_{ij}}(R_{ui}-\bar{R}_i)(R_{uj}-\bar{R}_j)}{\sqrt{\sum_{u\in U_{ij}}(R_{ui}-\bar{R}_i)^2}*\sqrt{\sum_{u\in U_{ij}}(R_{uj}-\bar{R}_j)^2}}$$

公式(4)

其中 $\bar{R}_i$ 和 $\bar{R}_j$ 分别表示所有评分用户对文档 i 和文档 j 的平均分。即:

图书情报工作
第 63 卷 第 16 期 2019 年 8 月

$$\bar{R}_i = \frac{1}{|U_{ij}|}\sum_{u \in U_{ij}} R_{ui},\ \bar{R}_j = \frac{1}{|U_{ij}|}\sum_{u \in U_{ij}} R_{uj} \qquad 公式(5)$$

文档 KNN 及综合过滤。即对每一个目标文档 i，在整个文档空间 I 中搜索文档集合 $I_1 = \{i'_1, i'_2, \cdots, i'_n\}$，使得 $i' \notin I_1$，并且 i' 与 i 的相似度 $sim(i, i')$ 降序排列。然后将 i' 过滤，去除掉其它用户所评文档，只保留目标用户 u 所评文档序列 I_2，然后根据 I_2 中各 i'' 被其他用户所评分数（可有下列启发性公式）来预测推荐文档 i'' 被目标用户 u 所采纳的程度 $P_{u,i''}$。

$$P_{i'',u} = \frac{1}{n}\sum_{i'' \in I} R_{u,i''},\ P_{i'',u} = \frac{\sum_{i'' \in I} sim(i, i'') \times (R_{u',i''} - \bar{R}_{i''})}{\sum_{i'' \in I} |sim(i, i'')|}$$

公式(6)

其中 I_1 是目标文档的最邻近集合，$R_{u',i''}$ 是为其他用户 u' 对过滤后的文档的评分，$R_{i''}$ 是为 u 对文档 i'' 的平均评分，也即 $P_{u,i''}$。需要说明的是，从 I_1 到 I_2 的过滤过程非常重要，因为这确保了推荐文档集合 I_1 存在于用户 u 所评论（或浏览）过的文档集合中。

4.3 网络推理推荐

贝叶斯网络（bayesian network）经过近 30 年的发展，已经被证明是一种高效的近似推理算法[45]，并且在信息检索与推荐、人工智能、专家系统、模式识别等领域都得到了成功应用。网络推理推荐（inference network recommendation，INR）模型[46]是一种基于贝叶斯网络的不确定性推理算法，它利用贝叶斯网络的结构及其条件概率表，计算各节点的取值概率。面向知识找回场景的推荐系统旨在通过行为记录捕获用户与文档间潜在的依赖关系，其算法是：首先构建文档的索引词出现事件序列 $\bar{k}_1$，给定文档观察事件 d_j 发生的先验概率和 k_i 出现事件的条件概率，得出检索词出现事件的后验概率，即可算出用户查询被满足的后验概率。通过文档观察事件－索引词出现事件－用户查询被满足事件这一推理链中各节点的条件独立性关系来构造一个贝叶斯网络 $BN = <X, A, \theta>$，得到推荐文档集合。其中查询词可根据用户记忆时所处状态（在本实验中，查询词为用户被分配的主题）得出。$<X, A>$ 表示一个有向无循环图 DAG，X 表示下文所述各类节点，A 表示相关节点潜在概率依赖关系，θ 表示 X 的条件分布概率，它量化了节点对其父节点的依赖程度。开源的信息检索工具 Indri 结合了网络推理模型和语言模型（language modeling）的优点，能很好的支持结构化查询（structured query），从而对推理网络中的节点进行有效预估[47]，能作为基于概率理论进行文档推荐的代表性工具，它所采用的基于 TF-IDF 实现文档节点 d_j 到检索词节点 t_k 的推理。图 2 是 Indri 的推理网络模型。

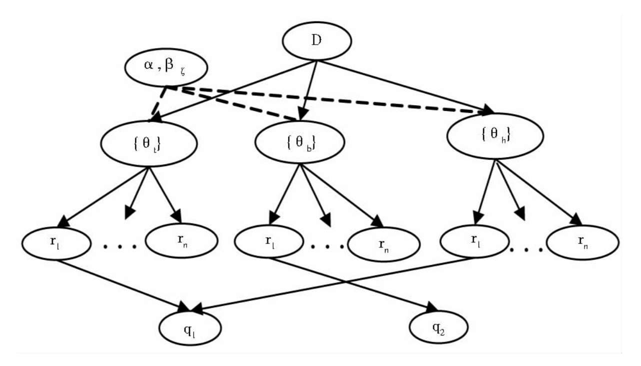


图 2 Indri 推理网络模型

图 2 中每一个节点代表一个随机事件，每个非根节点表示一个条件概率表，该表用来描述给定父节点的情况下该节点出现相关联的结果集的概率，系统利用给定的先验概率、条件概率和节点事件计算各文档被查询的概率，据此进行排序并输出。其中文档节点 D 是一个二进制特征向量；模型节点 θ 为一组经过 $M(\alpha, \beta)$ 平滑过的多元伯努利分布。在本文所述实验中，对预估文档的表示，记为 $P(\theta \mid D)$；特征节点 r 表示文档中任何易于被索引的特征，那么有：

$$P(r|D) = \frac{P(D|M)P(M)}{\int P(D|M)P(M)dM} = \frac{TF_{r,d} IDF_r}{|D|} \qquad 公式(7)$$

公式 7 表示假设一个文档一旦被观察到，那么对于每一个特征节点出现的概率，查询节点 q 用来合并特征节点的条件概率。本文按照 Indri 的工作原理进行模拟实现，通过在 Indri 中输入每人的 M_A 文档序列，从推理网络中得到其对应的 Indri 值 I，根据每人的 I 值进行排序，然后与 M_A 进行比对，所得结果形式如表 1 所示：

表 1 INR 推荐结果比对

* User	ID	M_{Ai}	R	I(Indri)	M_{Bi}
1	1	8	8	0.325 196 252	9
1	2	6	6	0.041 227 371	8
1	3	9	9	0.019 126 99	16
1	4	10	10	0.018 069 445	17
1	5	17	17	0.011 333 865	14
1	6	14	14	0.011 095 502	6
1	7	15	15	0.008 886 901	3
1	8	13	13	0.007 074 106	0
1	9	7	7	0.006 728 622	1
1	10	12	12	0.005 564 768	2

去除表 1 中排序靠后的 5 篇文档（M_{Ai} 共有 15 篇，M_{Bi} 共有 10 篇），得到推荐集 R 与 M_{bi} 的重合部分，带入下文评价标准中进行测量。

4.4 情境感知推荐

基于情境感知的推荐(context awareness system，CAS)不同于以上 CBR 等，它可以根据情境信息 H_{Bi} 判断用户当前情境，并将历史信息 H_{Ai} 应用于推荐过程之中，使推荐结果更符合用户当前所处情境预期。根据知识找回场景的特点，本文主要根据用户浏览记录 H_{Ai} 和 H_{Ai} 中所包含的情境信息进行推理。同时，鉴于知识间的关联性，本文选取激活扩展(spreading activation technique，SA)模型来进行情境信息推导[48]。SA 模型首先应用于信息检索领域，具有语词扩展功能[49]。例如，两个语词在 SA 方法中存在共现或者语义关联，如果其中一个语词是某篇文档的标引词，那么另一个语词也可标引该文档。从用户角度来看，它在一定程度上对用户记忆进行了扩展和延续，SA 模型可构建清晰的知识信息网络，可抽取与用户当前情境信息相关的情境信息，犹如在知识工作者的大脑中增加了记忆功能，减轻信息过载的压力，提高工作效率[50]。本文所做实验中，采用文档名中的关键词做文档标引。

首先，基于 SA 模型构建基于文档推荐的层次模型，见图 3。该模型主要包括事件层、情境层和文档层，不同层次在推荐过程中具有不同的功能。

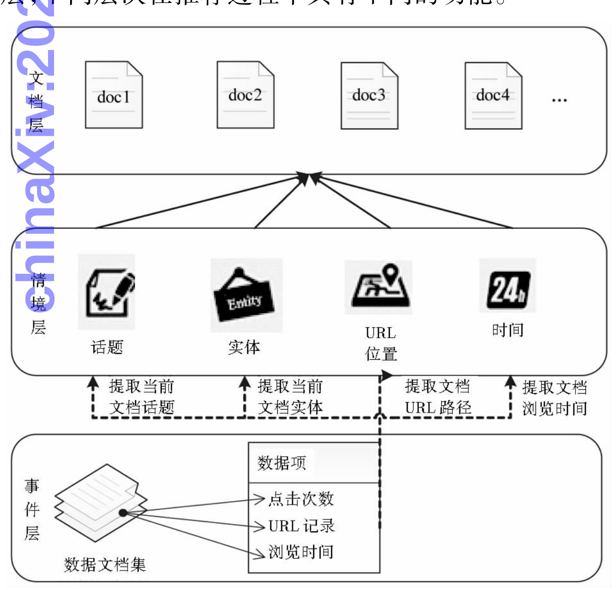


图 3 情境感知推荐中的层次模型

其次，根据以上 3 层结构建立激活扩展模型整体网络。事件层包含离散的用户事件信息(见表 2)，例如浏览、点击等事件等。在本文中，IE－History－View 记录包括鼠标活动、浏览框标题、URL 等实时数据。将一次打开事件列为一个 Event Block，以文档名标引其主题。这样，事件层里就包含了若干标引过的事件(event)序列。事件层为下一层的情境信息抽取提供了数据保障，是整个情境感知推荐模型的输入。

表 2 事件层内容举例

事件数据项	样本值
用户	Huanlei(某用户)
Event_ID	2344
开始时间	201734355T2315454
经过时间	48s
访问次数	4
URL	DELL@ file:///C:/Users/DELL/Desktop/实验/实验文档/实验搜索库 1－萧红/百度/百度_萧红简介/百度_萧红的资料与作品介绍. txt
标引(Topic)	萧红简介
位置/域/点击	NULL

然后，根据事件层的数据结构，将情境信息进行分类，并在情境层构建情境信息网络。因此，情境层主要包含各类型情境信息的节点，以及一个通过 SA 模型构建起来的情境信息网络。本文将情境信息分为 4 种基本类型：地点、时间、客体(Objects)以及活动(Activity)[20,28]，其中客体是指推荐项目；活动视具体情况而定，本文的活动主要是用户(知识工作者)对知识性文档的查找与浏览。据此，笔者将知识找回场景下的情境信息包含时间(Time)、话题(Topic)和实体(Entity)。其中，话题用来判断知识工作者当前工作主题范围，实体指当前打开文档。

最后，通过情境信息网络中的关联信息，对用户当前情境进行判断，根据文档的标引(也即上文所指话题)在文档层进行文档之间的关联与匹配。在文档层，运用 SA 方法，构建候选文档间的关联网络，并根据文档间关联强度对候选文档进行排序以便推荐。因此，融入 SA 方法的情境推荐具体过程为：一方面，对事件层的情境数据进行提取，提供给情境信息层，通过 SA 方法构建情境信息关联网络；另一方面，根据当前的情境描述信息，选择被标引文档进行匹配激活，然后利用匹配算法[51](此处用到了知识词库 WorldNet，查询标引之间的关联度)，对激活文档的相关文档进行激活，再对激活过后的相关文档进行排序推荐。例如，通过情境监测发现知识工作者正处于"癌症"话题，系统就会根据情境层的情境信息网络，通 SA 方法关联到语义相关的"肿瘤"话题，因此"肿瘤"话题相关情境信息被激活，文档层也将推出扩展文档。由此可见，SA 方法可以很好地解决了文档推荐中所面临的情境信息稀疏性问题。在本文中所做实验中，用户的每一主题的文档的存储量和记录数相对有限，这将使得文档层可能面临由于过度扩展所带来的推荐结果准确性较低，即

不相关文档被推荐出。因此，利用词频 TF－IDF 思想对 SA 模型的情境信息与文档关联强度加以限制。在 TF－IDF 中，字词的重要性与它在文档中出现的次数成正比，但与它在语料库中出现的频率成反比。同理，本文中规定，推荐文档的重要性与情境信息成正比，同时与总体情境信息成反比。也就是说，情境信息出现在越多的不同文档中，其相对文档的重要性越低；情境信息在同一文档中出现的次数越多，其相对该文本越重要。具体构建了不同层级间及其内部节点的联结权重计算方式如表 3 所示：

表 3　情境信息中不同层级间及其内部节点联结权重计算方式

情境信息项	权重计算方式	说明
Data/Time	1	时间戳是用户浏览的唯一标识，同一时刻只能认真浏览一篇文档
Entity	$(entity_x \in docment)/entities$	某一客体在文档之中出现的概率
Loca: Localtion	1	一个文档的存储路径一般是唯一的
Topic	$topic_x/topic_{1,n}$	某一话题的扩展权重取决于该话题在文档中出现的概率
ClickCount	$ClickCount_x/Max(ClickCount_x)$	该文档的点击次数与最高点击次数的比值

鉴于本文中文档的匹配主要取决于话题的匹配，话题影响着推荐文档的主题范围，并且在时间和位置情境的辅助下可给知识工作者推荐出符合其任务主题的、近期浏览的相关文档资料。情境推荐对于推荐结果主要关注推荐文档的情境相关，以预测知识工作者接下来的文档偏好。通过 *Latent Dirichlet Allocation*（*LDA*）方法对文档内容主题进行话题抽取，并同其他文档浏览记录信息结合标记文档特征。

5　评价体系

很多学者针对各种推荐方法的适用场景及推荐需求设置了同种类的评估标准[52]。但大多数学者只局限于推荐的精确性一个方面，而对多样性、预测性、实时性等指标论述较少。根据用户在知识找回场景下的具体推荐需求，结合 F. Ricci[2] 和 M. Sappelli[20] 的 4 组推荐系统的标准：①精确性（推荐集与用户主观需求的交集）；②情境相关性（推荐集与用户当前所处情境匹配程度，情境信息由用户浏览的文档名、时间间隔等描述）；③预测性（推荐集与用户下一时段将要打开的文档集匹配程度）；④多样性（推荐集 *R* 涵盖相同主题下不同子目录的程度），在每种标准之下涉及到的多种具体评价指标中（如 MAE 值、P/R 值，P@N 值、F 值、ROUGE－N[53] 等），每种评价指标里选取一至两种评价参数进行评价。

5.1　精确性评价标准

推荐的精确性用来评估推荐集合 *R* 与用户主观推荐需求 M_B 的重合程度，它类似于信息检索系统中的查准率。推荐系统精确性的提高可以减少不相关文档的干扰，帮助知识工作者更好地聚焦精力处理手中事务。一般情况下，用户只关心排名靠前的推荐文档。所以本文仅针对排名前 10 的推荐文档，计算查准率 P 值。具体为，对每位用户 *i*，其在 B 时段选择的文档集 M_{Bi} 与推荐集 *R* 个数的比值，记为

$$\overline{Precision} = \left(\sum_{i=1}^{k} R/M_{Bi}\right)/k \qquad \text{公式(8)}$$

其中 *k* 为用户的个数。

5.2　情境相关性评价标准

情境相关性评价标准用来评估推荐集 *R* 文档与用户当前所处情境的匹配程度。情境相关性评价标准可以至少反映推荐系统 3 个方面的效率：①可以体现推荐结果是否能连续匹配所有情境下的信息需求；将用户所做工作看做是一个顺序发生的情境序列 $S_i < s_1, \cdots, s_n >$，用户在 t1 时刻所处的情境所需推荐结果并不一定满足用户在 t2 时刻所处情境的需求。例如，一个用户写一篇软件工程文档，在开始写的时候，用户关心的是系统需求，而接下来的某一端时间，用户可能更关心界面设计。②可以体现推荐系统在多大程度上分散用户注意力的能力[20]。③可以衡量推荐系统理解用户所处情境的能力。以上 3 个方面的效率的提升可以更好地提醒用户哪些文档是其过去浏览过且与现在进行的知识工作情境相关的。

在本文所做实验中，采用情境计算中 3 个经典变量组成的三元组：*Context* = < 时段 *time*，目录 *index*，激活文档（即当前打开文档）*document* >，作为描述用户当前情境的参数，且均可以从 B 时段的浏览记录 H_{Bi} 中得到。那么，接下来的任务就变为：如何衡量推荐集 *R* 与 B 时段用户经历的情境相关文档集 *Context* 的匹配程度？具体公式为：

$$\overline{Context} = \frac{\sum_{i=1}^{k}(Contexm.time) * Num_i(Context.index)}{\sum_{i=1}^{k} Num_i(Context)} * \sum_{i=1}^{k} sim(documents, R_i) \qquad \text{公式(9)}$$

公式 9 中，$Num_i(Context.time)$ 示给每个用户的推

荐集 $R(R=10)$ 与用户在时间间隔（取 3min）内打开的文档为同一文档的数量；$Num_i(Context.\ index)$ 表示 R 与该用户打开所有文档属于同一子目录的数量；$sim(documents, R_i)$ 表示用户打开文档主题（文件名）与 R 的相似度，可以通过余弦公式求得；$Num_i(Context)$ 表示用户经历过的情境个数，在这里，用打开文档数代替。接下来，需要设立 $\overline{Context}$ 的阈值，表示 $Context < c_1 \cdots c_n >$ 达到多少百分比即判定推荐文档与用户情境相关。经试验，阈值取 0.04 时，每组主题中均存在匹配成功的文档。接下来，仍用 P@N 指标衡量情境相关质量：如果推荐文档列表 $R < r_1 \cdots r_{10} >$ 与 B 时段用户经历情境相关文档集 $Context < c_1 \cdots c_n >$，则匹配成功。

5.3 预测性评价标准

如前文所述，推荐的目的是提醒用户“将要”使用什么，而不是用户“喜欢过”什么。与“喜欢过”的东西非常相关的内容，有可能帮助用户工作，但是并不一定符合用户“下一步”的预期。因此，预测性的评价指标旨在从另一个角度评价推荐系统能力：推荐结果是否能够有效预测用户下一步将要打开的文档，这无疑将会节省用户选取其真实所需文档的时间。采用记录事件框的方法来获取用户“下一步”需要的文档，具体为：将 B 时段分为 3 个时间间隔（10min * 3），用每一个推荐模型的推荐集合 R 与后两个时段打开文档进行比对，通过计算 R 中包含用户下一步打开文档数量以衡量推荐系统预测性指标 Prediction：

$$\overline{Perdiction} = \frac{\sum_{i=1}^{k} Num(R_i T_2) + \sum_{i=1}^{k} Num(R_i T_3)}{2N} \quad 公式(10)$$

其中，$Num(R_i T_j)$ 表示对于用户 i 来说，推荐集 R 与 Tj 时间间隔内用户打开的文档重合的数量。同样本文采用了 Prediction@1 和 Prediction@10 的方法计算文档的比率值。

5.4 多样性评价标准

对于用户来说，完成一项任务将涉及到各个领域的知识，因此，推荐文档集合的多样性对于满足用户对知识广度的需求非常重要，可以充分激发知识创造力。但是多样性评价标准与其它评价标准存在一定的矛盾性，因为推荐集的多样性的提高，在一定程度上会降低相关文档的数量。但是只要文档集合充裕，在不降低相关性的条件下，保持推荐集的多样性是可行的。在本文所做实验中，推荐集合的多样性是指推荐集 R 涵盖相同主题下不同子目录的程度。将推荐集合中来自于同一最小子目录（如表 3 中 URL 所示，在‘实验文档’目录下又有三层子目录，分别为一、二、三层子目录）的文档归为一组，每组的文档数如大于等于 2，则除以该组文档数。最后，再除以总用户数。这样来计算推荐文档集的多样性。

6 实验结果与分析

本文根据实验需要，组织了 20 人的志愿者团队。因时间有限，本次实验对于每个用户只启用一个主题来进行评测，最终进行汇总分析。利用课余时间开展模拟实验一，四周之后开展模拟实验二，记录采集到的用户行为数据、用户每次实验所选文档，然后利用上述 4 种标准对上述 4 种典型推荐系统进行进行效果评估。结果如下：

6.1 精确性

表 4 显示了各种推荐系统在精确性（查准率）方面的情况，图中 P@1 表示推荐列表与用户主观选择在第一项上的重合率，P@10 表示推荐列表的前 10 项与主观选择的重合率。在推荐精度上，CFR 与 CAS 在随机性方面明显低于 CBR 与 INR，因为 CAS 方法试图在推荐文档的同时，对情境进行分类，所有推荐集 R 与情境集 Context 存在一定的关系，但对查准率并没有太大贡献；而 P@1 与 P@10 分布最为不均匀的是 CBR 和 CFR；虽然基于内容的推荐方式和协同推荐在排序靠前部分取得较好质量，但是衰减非常快。

表 4 知识找回场景下的推荐系统精确性

方法	CBR	CFR	INR	CAS
Precition@1	0.65	0.50	0.55	0.50
Precition@10	0.58	0.45	0.60	0.44

6.2 情境相关性

表 5 显示了 4 种推荐系统在情境相关性方面的情况，表中 Context@1 表示推荐列表与情境相关文档集 Context 中，第一项的公式计算出的匹配度，Context@10 表示推荐列表的前 10 项与情境相关文档集 Context 的公式计算出的匹配度。如表 5 所示，在“用户所得到的推荐集合是否符合当前情境”指标上看，CAS 得分最高，这证明了 CAS 在“知识找回”场景中具有比 CFR 和 INR 等传统模型更高的情境感知能力。另外，在实验中发现，激活扩散模型中情境项的计算方式与 Context@N 非常相关。例如，去掉“文档点击次数”的情境信息，能够非常大程度影响情境相关文档集 Context 的抽

取,继而影响情境相关性。

表 5 知识找回场景下的推荐系统情境相关性

方法	CBR	CFR	INR	CAS
Context@ 1	0. 690	0. 369	0. 578	0. 728
Context@ 10	0. 567	0. 397	0. 401	0. 583

6.3 预测性

表 6 显示,CAS 在预测用户下一时段需求方面具有更好的能力。CBR 在推荐清单中正确预测下一份文件的能力仅维持在 3% 左右,而 CFR 对预测性的波动较大,但均没有 CBR 有效;INR 的预测能力最弱(< 2%),而 CAS 的预测能力在后半段时间内能达到接近 4% 。需要说明的是,由于下一时段的推荐集不能包含当前时段的打开文档,用户往往在打开文档之后没有关闭它,而是在下一时段对原来的文档来回切换,因此无法预测许多被重复切换浏览的文档。

表 6 知识找回场景下的推荐系统预测性

方法	CBR	CFR	INR	CAS
Prediction@ 1	0. 027	0. 009	0. 012	0. 021
Prediction@ 10	0. 033	0. 033	0. 015	0. 037

6.4 多样性

表 7 显示,推荐系统中 INR 和 CAS 具有较高的多样性。这说明 CAS 在适应对情境变化方面差异较其他推荐系统大,其次是 CBR 和 CFR。

表 7 知识找回场景下的推荐系统多样性

方法	CBR	CFR	INR	CAS
Diversity	1. 80	1. 60	1. 45	2. 00

6.5 推荐系统比较分析

分别对以上 4 种推荐系统的 4 种评估标准在推荐结果匹配度 P@ 1 至 P@ 10 上进行了可视化,结果见图 4 – 图 7。

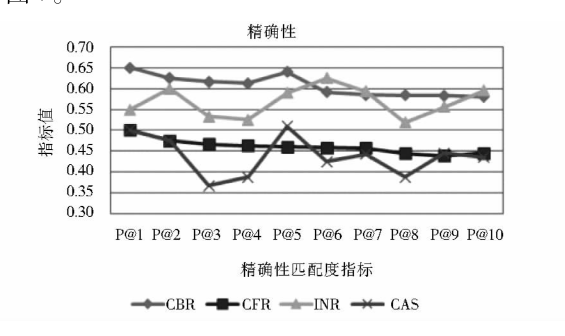


图 4 4 种推荐系统精确性比较

比较结果显示,在推荐系统的精确性上,情境感知类推荐系统较其他推荐系统有较大波动,一定程度上说明了情境相关与文档相关的分离性,即基于文档相关的 CBR 推荐结果更多的是取决于文档内容,而 CAS 更多取决于用户当前所处情境。因此在推荐列表的选择上,推荐个数的增多意味着涵盖的情境增多。如果系统的目标是推荐可能包含用户当前情境下的相关文档,则 CBR 与 CAS 都是最佳选择。从图 5 可知,CAS 虽然具有更高的情境适应能力,但这并不是说 CAS 用户一定就会使用这些情境相关的文档。事实上,随着 CAS 推荐列表的增大,该列表对所有情境的满足程度将会衰减,而 CBR 与 INF 则没有这个问题。另外,需要指出的是,用户的一项不容易被测量的需求是防止推荐系统对用户的干扰。在这方面具有情境感知功能的 CAS 与具有情境预过滤功能的 CBR 都能取得较好的结果。如果系统目标是预测用户即将打开哪些文档,那么 CAS 是最佳选择。因为基于 CAS 的推荐系统中,推荐列表与该情境下被激活扩散的相关文档之间有直接关联,并且这种关联不随时间变动而改变。本

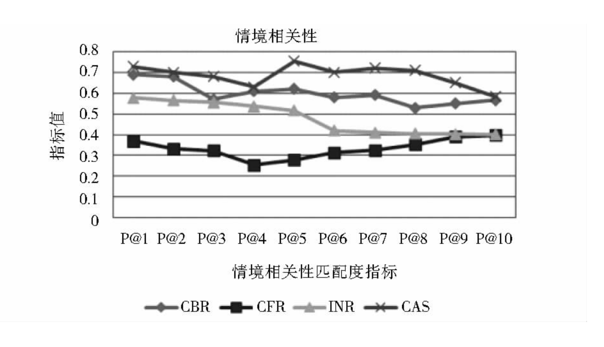


图 5 4 种推荐系统情境相关性比较

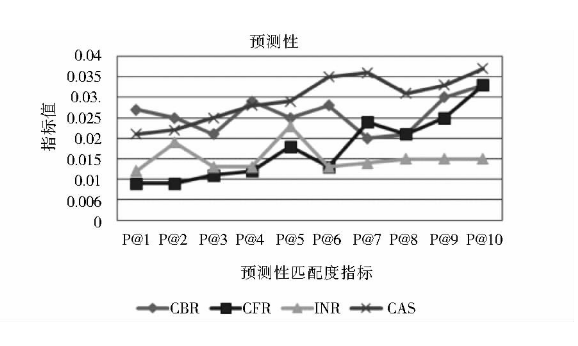


图 6 4 种推荐系统预测性比较

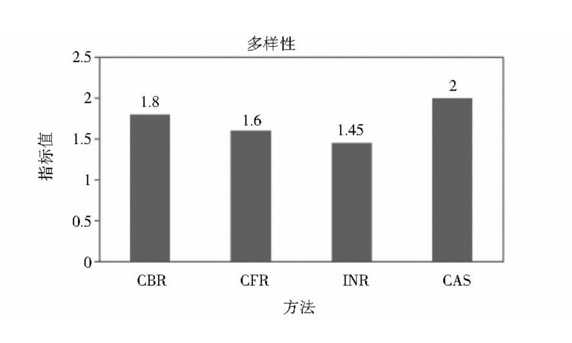


图 7 4 种推荐系统推荐内容多样性比较

文所做实验中,对于多样性检测比较简单,主要是因为实验中推荐列表最大值为10,对于检测推荐结果的多样性方面说明性较弱。由图7可知,CAS同样在多样性方面表现也较好,但是4种推荐系统在多样性方面表现差异不大。

上文提出的4种评估标准涵盖了知识找回场景下用户对推荐系统需求的几个方面。其中,一些评估标准可能与用户的显性需求相关,例如精确度;一些评估标准可能与用户的隐性需求相关,例如多样性。因为面向“知识找回”场景的推荐系统的应用主要体现在个人或团队的知识管理系统上,以本文的实验结果可以说明这些系统推广的有效性,可以为评估各类推荐系统是否在总体上适合大多数知识工作者的整体需求提供有效建议,在具体实施建设系统时倾向于选择在所有评估标准上得分较高的系统。但这并不是说在任何情况下本实验结论中评分较高的推荐系统都会表现最佳。一个实际例子是,如果用户所处情境相对集中(例如用户一天都在处理健康类文档),那么选用CAS可以防止干扰(disturbance)的发生。但如果情境信息较为分散(例如用户在多个情境间来回切换),那么CAS的抗干扰性将会明显减弱,而分散用户的注意力。

因此,可以得出结论,鉴于知识找回场景中多样化的用户需求,首选的推荐方案并非完全取决于推荐系统在实验中的评测结果,更应该取决于用户在知识找回场景中当前所进行的任务。实际上,不论它们在评估标准上表现如何,每种推荐系统都有其优缺点。CBR的优点在于方案简单、可靠,但它容易遇到引入一个新的情境所发生的冷启动问题。INR的优点是进行情境的确定不依赖外部信息,进而用情境词进行查询,但缺点是有时查询失败而不能提供任何推荐。在本实验中,有14%的情境词有这种情况。另外,在许多复杂场景中,首选的推荐方案即使在一天的工作中也会发生变化。故而,选择合适的推荐方案,重要的是在任务驱动下,确定适合的推荐方案并持续使用,充分消除冷启动问题。

7 结论

本文梳理了几种典型推荐系统的发展脉络。在此基础上,设计并执行实验流程,模拟实现了4种有代表性推荐系统的初级版本。随后根据知识找回场景下的用户需求,设置了4种评估标准,用来评估知识找回场景下各种推荐系统的效率。结果显示,各类推荐系统在“知识找回”场景中各有优势,基于情境感知的推荐系统在情境相关性与可预测性方面的表现较其他推荐系统更加突出。因而,在个人知识工作者或者小型团队的知识管理中可以根据实际工作需求和模型特点进行应用。

从模拟实验结果中也可以看出,构建在知识找回场景下的推荐模型是复杂的,它既要考虑到用户或用户群体的历史兴趣偏好,又要考虑到用户当前所处情境。当在大规模用户中进行推广时,既要考虑本文实验中所得出的一般性结果,又要结合用户在自身情境中的任务情况提供个性化的定制渠道。同时,笔者也认为,基于情境感知的推荐是一种具有较好发展前景的推荐系统,虽然其推荐列表可能在精度与灵活性方面有待提高,但是在系统建设时可以作为默认的推荐方式在其之上运用其他类型的推荐模型进行拓展。

未来工作将考虑如何把非情境推荐的模型与情境推荐的模型加以融合,充分发挥各自优势,并将隐语义模型、深度学习模型等新兴推荐模型纳入研究之中。后续将比较各类模型在有无情境信息时的表现差异,通过引用激活扩散模型来挖掘情境相关文档,构建情境描述机制,更好地探究各类模型在知识找回场景下的适用性。

参考文献:

[1] BAWDEN D, ROBINSON L. The dark side of information: overload, anxiety and other paradoxes and pathologies[J]. Journal of information science, 2009, 35(2):180－191.
[2] RICCI F, ROKACH L, SHAPIRA B, et al. Recommender systems handbook[M]. Berlin: Springer, 2011.
[3] SCHAFER J B, DAN F, HERLOCKER J, et al. Collaborative filtering recommender systems[M]. Berlin: Springer, 2007.
[4] BELL R M, KOREN Y. Scalable collaborative filtering with jointly derived neighborhood interpolation weights[C]// Proceedings of the seventh IEEE international conference on data mining. Washington: IEEE Computer Society, 2007:43－52.
[5] MANOUSELIS N, VUORIKARI R, ASSCHE F V. Collaborative recommendation of e-learning resources: an experimental investigation[J]. Journal of computer assisted learning, 2010, 26(4):227－242.
[6] 熊回香,杨雪萍,高连花,等.基于用户兴趣主题模型的个性化推荐研究[J].情报学报,2017,36(9):916－928.
[7] 王玙,刘东苏.基于联合聚类与用户特征提取的协同过滤推荐算法[J].情报学报,2017,36(8):852－858.
[8] DOAN A H. Learning to map between ontologies on the semantic web[C]// Proceedings of the eleventh international conference on World Wide Web. New York: ACM, 2002:622－673.
[9] BRASETHVIK T, GULLA J A. Natural language analysis for semantic document modeling[J]. Data & knowledge engineering,

2001, 38(1):45 – 62.
[10] KIM J H, SONG C W, LIM K W, et al. Design of music recommendation system using context information[C]//Proceedings of the 2006 Pacific Rim international conference on agent computing & multi-agent systems. Berlin: Springer, 2006:708 – 713.
[11] 王玙, 刘东苏. 基于联合聚类与用户特征提取的协同过滤推荐算法[J]. 情报学报, 2017, 36(8):852 – 858.
[12] MA H, ZHOU T C, LYU M R, et al. Improving recommender systems by incorporating social contextual information [J]. ACM transactions on information systems, 2011, 29(2):1 – 23.
[13] LIU N N, HE L, ZHAO M. Social temporal collaborative ranking for context aware movie recommendation[J]. ACM transactions on intelligent systems and technology, 2013, 4(1):1 – 26.
[14] WANG X, ROSENBLUM D, WANG Y. Context-aware mobile music recommendation for daily activities[C]// Proceedings of the 20th ACM multimedia. New York: ACM, 2012: 99 – 108.
[15] ELSWEILER D, RUTHVEN I, JONES C. Towards memory supporting personal information management tools[J]. Journal of the American Society for Information Science & Technology, 2007, 58(7):924 – 946.
[16] REINHARDT W, SCHMIDT B, SLOEP P, et al. Knowledge worker roles and actions - results of two empirical studies [J]. Knowledge & process management, 2011, 18(3):150 – 174.
[17] WANG W, LI W, WU Z, et al. An ontology-based context model for building context-aware services[C]// Procedings of the second international conference on intelligent systems, Modelling and Simulation. Washington: IEEE Computer Society, 2011:296 – 299.
[18] WAKELING S, CLOUGH P, SEN B. Investigating the potential impact of non-personalized recommendations in the OPAC: Amazon vs WorldCat. org[C]// Proceedings of the fifth information interaction in context symposium. New York: ACM, 2014:96 – 105.
[19] CHARI S, CHRISTODOULIDES G, PRESI C, et al. Consumer trust in user - generated brand recommendations on Facebook[J]. Psychology & marketing, 2016, 33(12):1071 – 1081.
[20] SAPPELLI M, VERBERNE S, KRAAIJ W. Evaluation of context - aware recommendation systems for information re - finding[J]. Journal of the Association for Information Science & Technology, 2017, 68(4):895 – 910.
[21] AULA A. Information search and re-access strategies of experienced web users[C]// Proceedings of the 14th international conference on World Wide Web. New York: ACM, 2005:583 – 592.
[22] TEEVAN J, ADAR E, JONES R, et al. Information re-retrieval: repeat queries in Yahoo's logs[C]// Proceedings of the 2007 International ACM Sigir conference on research & development in information retrieval. New York: ACM, 2007:151 – 158.
[23] OBENDORF H, WEINREICH H, HERDER E, et al. Web page revisitation revisited: implications of a long-term click-stream study of browser usage[C]//Proceedings of the 2007 SIGCHI conference on human factors in computing systems. New York: ACM, 2007: 597 – 606.
[24] TAUSCHER L, GREENBERG S. Revisitation patterns in World Wide Web navigation[C]// Proceedings of the 1997 ACM SIGCHI conference on human factors in computing systems. New York: ACM, 1997:399 – 406.
[25] COCKBURN A, MCKENZIE B. What do web users do? an empirical analysis of web use[J]. International journal of human - computer studies, 2001, 54(6):903 – 922.
[26] WEN J. Post-valued recall web pages: user disorientation hits the big time[J]. IT & society, 2003, 1(3): 184 – 194.
[27] HARPER S. Integrating memory context into personal information re-finding[C]//Proceedings of the 2nd BCS-IRSG conference on future directions in information access. London: British Computer Society, 2008:14 – 21.
[28] DENG T, ZHAO L, WANG H, et al. ReFinder: a context-based information refinding system[J]. IEEE transactions on knowledge & data engineering, 2013, 25(9):2119 – 2132.
[29] VÖLKEL M, ABECKER A. Cost-benefit analysis for the design of personal knowledge management systems [J]. Proc of ICEIS, 2009, 6030(1):95 – 105.
[30] GOLDBERG D. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12):61 – 70.
[31] RESNICK P, IACOVOU N, Suchak M, et al. GroupLens: an open architecture for collaborative filtering of netnews[C]//Proceedings of the 1994 ACM conference on computer supported cooperative work. New York: ACM, 1994:175 – 186.
[32] 阮光册, 夏磊. 推荐系统的发展与公共图书馆个性化信息服务探讨[J]. 图书馆, 2016, 2016(2):94 – 99.
[33] BAEZA-YATES R, RIBEIRO-NETO B. Modern Information Retrieval[M]. New York: ACM Press, 1997.
[34] RESNICK P, VARIAN H R. Recommender systems[J]. Communications of the ACM, 1997, 40(3):56 – 58.
[35] LI Y, LU L, LI X. A hybrid collaborative filtering method for multiple-interests and multiple-content recommendation in E-Commerce [J]. Expert systems with applications, 2005, 28(1):67 – 77.
[36] JI A T, YEON C, KIM H N, et al. Collaborative tagging in recommender systems[M]. Berlin: Springer, 2007.
[37] WOOLDRIDGE M J. An Introduction to Multiagent Systems[M]. Chichester: John Wiley & Sons, 2002.
[38] ADOMAVICIUS G. Incorporating contextual information in recommender systems using a multidimensional approach [J]. ACM transactions on information systems, 2005, 23(1):103 – 145.
[39] LI Y, ZHANG D, LAN Z, et al. Context-aware advertisement recommendation for high-speed social news feeding[C]//Proceedings of the 2016 international conference on data engineering. Washington: IEEE Computer Society, 2016:505 – 516.
[40] LOMMATZSCH A. Real-time news recommendation using context-aware ensembles[C]// Proceedings of the 2014 European confer-

ence on information retrieval. Berlin: Springer, 2014:51－62.

[41] GOLDBERG D. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12):61－70.

[42] IEHistoryView [EB/OL]. [2017－09－24] https://iehistory-view.en.softonic.com/.

[43] GOLDBERG D, NICHOLS D, OKI B, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12), 61－70.

[44] AHN H J. A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem[J]. Information sciences, 2008, 178(1):37－51.

[45] NAGARA R, SCUTARI M, LÉBRE S. Bayesian network inference algorithms[M]. Berlin: Springer, 2013.

[46] TURTLE H, CROFT W B. Evaluation of an inference network-based retrieval model[M]. New York: ACM, 1991.

[47] STROHMAN T, METZLER D, TURTLE H, et al. Indri: a language-model based search engine for complex queries[C]// Proceedings of 2005 IEEE international conference on information and automation. New York: ACM, 2005:1－34.

[48] MCCLELLAND J L, RUMELHART D E. An interactive activation model of context effects in letter perception, part i: an account of basic findings[J]. Psychological review, 2013, 88(5):375－407.

[49] CRESTANI F. Application of spreading activation techniques in information retrieval[M]. Dordrecht: Kluwer Academic Publishers, 1997.

[50] 田野，杨眉，祝忠明，等.关联数据驱动的查询扩展技术研究[J]. 图书情报工作，2015，59(4):122－128.

[51] DEY A K, ABOWD G D. CybreMinder: a context-aware system for supporting reminders[C]// Proceedings of the 2nd international symposium on handheld and ubiquitous computing. Berlin: Springer, 2000:172－186.

[52] LÜ L Y, MEDO M, CHI H Y, et al. Recommender systems[J]. Physics reports, 2012, 519(1):1－49

[53] FLICK C. ROUGE: A package for automatic evaluation of summaries[C]//Proceedings of the workshop on text summarization branches out. Stroudsburg: ACL, 2004:1－105.

作者贡献说明：

程秀峰：提出研究框架与论文撰写；
张孜铭：设计实验方案与论文修订；
孟亚琪：资料搜集与数据采集；
范晓莹：资料搜集与数据采集；
杨金庆：数据分析与论文撰写。

An Experimental Study on Simulation and Evaluation of Recommendation Systems for Knowledge Re-finding

Cheng Xiufeng　Zhang Ziming　Meng Yaqi　Fan Xiaoying　Yang Jinqing
School of Information Management, Central China Normal University, Wuhan 430079

Abstract: [**Purpose/significance**] Information overload has been always considered as the major barrier confronted by knowledge workers in the process of gathering, processing and producing information. One of its consequences is that it is hard to recall documents that ever used, while the recommendation system could reduce such difficulty. Comparing the recommendation efficiencies through representative recommendation mechanisms may assisst knowledge workers in accomplishing the task of knowledge re-finding. [**Method/process**] Based on associated recommendation system theoies, this paper presents a simulation on 4 different recommendation procedures in an unified experimental scene(knowledge re-finding), the precedures includes CBR, CFR, INR and CAS. 4 evaluation criteria (precision, context-relevance, action-prediction, diversity) has been used to evaluate and compare the efficiency of corresponding recommendation systems. [**Result/conclusion**] The results show that each recommendation procedure has its own advantages in knowledge re-finding from different perspectives, and CAS has advantages in both context-relevance and action-prediction.

Keywords: information overload　knowledge re－finding　recommendation system　context-awareness

更正说明

发表在本刊2018年第18期的《社交媒体用户转移行为影响因素模型及实证研究》一文，第四作者应为韦雅楠，错写为韦亚楠，特此更正。